

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA POLITÉCNICA E DE ARTES
CIÊNCIA DA COMPUTAÇÃO**



**VISÃO COMPUTACIONAL PARA O AUXÍLIO NA EXECUÇÃO DE POSES NO
FISICULTURISMO**

LUIZ SABINO DA SILVA BISNETO

GOIÂNIA

2025

LUIZ SABINO DA SILVA BISNETO

**VISÃO COMPUTACIONAL PARA O AUXÍLIO NA EXECUÇÃO DE POSES NO
FISICULTURISMO**

Trabalho para conclusão de curso apresentado na Escola Politécnica e de Artes da Pontifícia Universidade Católica de Goiás como requisito básico para a conclusão do curso de Ciência da Computação.

Orientador: Prof. Me. Gustavo Siqueira Vinhal

GOIÂNIA
2025

LUIZ SABINO DA SILVA BISNETO

**VISÃO COMPUTACIONAL PARA O AUXÍLIO NA EXECUÇÃO DE POSES NO
FISICULTURISMO**

Este Trabalho de Conclusão de Curso foi julgado adequado para a obtenção do título de Bacharel em Ciência da Computação, e aprovado em sua forma final pela Escola Politécnica e de Artes, da Pontifícia Universidade Católica de Goiás em ____/____/____.

Banca examinadora:

Prof. Me. Gustavo Siqueira Vinhal

Prof. Me. Carlos Alexandre Ferreira de Lima

Prof. Me. Fernando Gonçalves Abadia

GOIÂNIA
2025

Dedico este trabalho aos meus pais, Maria Auristela Gomes da Silva e Luiz Sabino da Silva Neto, que sempre foram minha base e inspiração. Também ao meu irmão, Érico Souza Sabino da Silva, cuja trajetória me inspira como profissional e como pessoa.

AGRADECIMENTOS

A minha família e aos meus amigos, pelo apoio incondicional e pelos momentos inesquecíveis que tornaram minha jornada mais leve e significativa.

Ao meu orientador acadêmico, professor Me. Gustavo Siqueira Vinhal, pela confiança depositada em mim, pela paciência e pelo suporte essencial durante o desenvolvimento deste trabalho.

Aos professores com os quais tive a honra de aprender e conviver ao longo da minha trajetória acadêmica, cujos ensinamentos foram fundamentais para minha formação.

Sou grato a todo o corpo docente, à direção e à administração desta universidade.

E, por fim, a todos que, de alguma forma, contribuíram para a realização e concretização deste trabalho.

“There’s a lot of us out here that are birds. We all just need to fly.”

Jacques Berman Webster II

RESUMO

A visão computacional é uma área da inteligência artificial voltada para a interpretação automática de imagens e vídeos por computadores. No fisiculturismo, a execução correta das poses é um fator essencial, porém, normalmente avaliada de forma subjetiva pelos jurados. Este trabalho tem como objetivo o desenvolvimento de um sistema baseado em técnicas de *pose estimation*, utilizando a biblioteca *MediaPipe*, capaz de analisar poses de atletas e fornecer *feedback* automático em tempo real sobre postura e simetria corporal. Para isso, foram realizadas pesquisas bibliográficas e a implementação de um protótipo experimental que identifica pontos-chave do corpo e avalia parâmetros como ângulos articulares e centralização do atleta em frente à câmera. Os resultados obtidos incluem a validação de um sistema funcional que demonstre a aplicabilidade da visão computacional como ferramenta de apoio no aperfeiçoamento técnico de poses no fisiculturismo.

Palavra-Chave: Visão Computacional. *Pose Estimation*. *MediaPipe*. Fisiculturismo. *Feedback* Automático.

ABSTRACT

Computer vision is an area of artificial intelligence focused on the automatic interpretation of images and videos. In bodybuilding, the correct execution of poses is a crucial factor, yet it is often assessed subjectively by coaches and judges. This work aims to develop a system based on pose estimation techniques, using the MediaPipe library, capable of analyzing athletes' poses and providing real-time automatic feedback on posture and body symmetry. To achieve this, bibliographic research and the implementation of an experimental prototype were carried out, allowing the identification of key body points and the evaluation of parameters such as joint angles and the athlete's alignment in front of the camera. The achieved results include confirming the feasibility of a functional system that demonstrates the applicability of computer vision as a support tool for improving bodybuilding pose technique.

Keywords: Computer Vision. Pose Estimation. MediaPipe. Bodybuilding. Automatic Feedback.

LISTA DE ILUSTRAÇÕES

Figura 1 – Eugen Sandow.	17
Figura 2 – (a) John Grimek. (b) Steve Reeves.	18
Figura 3 – (a) Larry Scott. (b) Logo do Mr.Olympia.	19
Figura 4 – (a) Arnold Schwarzenegger. (b) Franco Columbu.	20
Figura 5 – Lee Haney.	21
Figura 6 – Dorian Yates.	22
Figura 7 – Ronnie Coleman.	23
Figura 8 – Chris Bumstead.	24
Figura 9 – Chris Bumstead executando o duplo bíceps de frente.	26
Figura 10 – Chris Bumstead (esquerda) e Ramon Dino (direita) executando a pose de duplo bíceps de frente no Mr. Olympia, 2023.	28
Figura 11 – Chris Bumstead treinando pose em sua academia privada.	29
Figura 12 – Jay Cutler (a) fora de temporada de dieta e (b) competindo no Mr. Olympia 2009.	30
Figura 13 – André “Pajé” Pierin e Fabrício Pacholok auxiliando Ramon Dino no ajuste de poses.	31
Figura 14 – Exemplo de aplicação de visão computacional na área médica - Detecção de tumor em ressonância magnética.	35
Figura 15 – Sistema de vigilância com <i>bounding boxes</i> .	36
Figura 16 – Inspeção automatizada de peças/embalagens em linhas de produção.	36
Figura 17 – <i>Pose Estimation</i> com esqueleto sobreposto a um atleta.	37
Figura 18 – Fluxograma da execução do sistema.	45
Figura 19 – Execução do sistema com sobreposição do esqueleto e ângulos articulares.	46
Figura 20 – Protótipo avaliando a pose de duplo bíceps corretamente.	49
Figura 21 – Protótipo identificando execução incorreta da pose de duplo bíceps.	49

LISTA DE SIGLAS

IA = Inteligência Artificial

FPS = *Frames Per Second* (Quadros por Segundo)

VRAM = *Video Random Access Memory* (Memória de Acesso Aleatório de Vídeo)

RAM = *Random Access Memory* (Memória de Acesso Aleatório)

BGR = *Blue, Green Red* (Formato de cores: Azul, Verde, Vermelho)

RGB = *Red, Green, Blue* (Formato de cores: Vermelho, Verde, Azul)

GPU = *Graphics Processing Unit* (Unidade de Processamento Gráfico)

GB = *Gigabyte*

SUMÁRIO

1	INTRODUÇÃO	13
1.1.	Motivação	14
1.2.	Objetivos	14
1.2.1.	Objetivo Geral	14
1.2.2.	Objetivos específicos	15
1.3.	Resultados esperados	15
1.4.	Estrutura do trabalho	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1.	Fisiculturismo e Qualidade de Poses	16
2.1.1.	Histórico do Fisiculturismo	17
2.1.2.	Poses Obrigatórias no Fisiculturismo	24
2.1.3.	CrITÉRIOS de Avaliação	26
2.1.4.	Importância da Qualidade das Poses nos Treinos	28
2.1.5.	Limitações da Avaliação Subjetiva	31
2.2.	Visão Computacional	32
2.2.1.	Conceitos Fundamentais	32
2.2.2.	Evolução Histórica	33
2.2.3.	Principais Aplicações	34
2.2.4.	Relevância para o Fisiculturismo	38
2.3.	Pose Estimation	38
2.3.1.	Conceitos e Métodos	39
2.3.2.	Extração de pontos-chave	40
2.3.3.	Aplicações em esportes e correção postural	40
3	SISTEMA DE ANÁLISE DE POSE	41
3.1.	Ambiente de Desenvolvimento	41
3.2.	Arquitetura do Sistema	42
3.3.	Implementação do Código	44
3.4.	Ferramentas e Bibliotecas Utilizadas	46

3.5.	Trabalhos Relacionados	47
4	RESULTADOS	49
5	CONCLUSÃO	51
5.1.	Trabalhos Futuros	51
5.2.	Considerações Finais	52
	REFERÊNCIAS	53
	APÊNDICE A – IMAGENS DOS TESTES	56
	APÊNDICE B – CÓDIGO FONTE	58

1 INTRODUÇÃO

A evolução da tecnologia e o avanço da inteligência artificial (IA) têm possibilitado o desenvolvimento de sistemas cada vez mais sofisticados para análise de dados visuais. Nesse contexto, a visão computacional destaca-se como uma área capaz de interpretar automaticamente imagens e vídeos, permitindo a extração de informações úteis para aplicações em segurança, saúde, esportes e entretenimento (SZELISKI, 2022). O progresso de técnicas como *machine learning* e *deep learning* contribuiu para aumentar a precisão desses sistemas, tornando-os ferramentas essenciais na resolução de problemas que demandam reconhecimento de padrões e análise em tempo real (GOODFELLOW; BENGIO; COURVILLE, 2016).

No âmbito esportivo, a visão computacional tem se consolidado como recurso valioso para avaliação de desempenho, prevenção de lesões e análise biomecânica (WU et al., 2021). Modalidades como atletismo, ginástica e futebol já utilizam sistemas baseados em detecção de movimento e *pose estimation* para monitorar gestos técnicos, fornecendo métricas objetivas que auxiliam tanto no treinamento quanto na arbitragem (ZHENG et al., 2020).

Dentro desse cenário, o fisiculturismo ocupa uma posição particular, pois exige precisão e perfeição na execução de poses, que são avaliadas rigorosamente em competições segundo critérios de simetria, volume, proporção e estética (IFBB, 2023; SCHOENFELD, 2010). Entretanto, a análise da performance dos atletas ainda é predominantemente subjetiva, baseada na experiência de juízes e treinadores (SANTANA; VIEIRA, 2019). Essa subjetividade pode gerar inconsistências na avaliação, além de limitar a autonomia do atleta durante seus treinos individuais.

Diante dessa realidade, a utilização da visão computacional como ferramenta de apoio torna-se uma perspectiva promissora. O uso de técnicas de *pose estimation*, capazes de identificar pontos-chave do corpo humano e calcular ângulos articulares, abre caminho para avaliações mais objetivas e em tempo real (CAO et al., 2017; FANG et al., 2022). Essa tecnologia pode fornecer *feedback* imediato sobre a execução das poses, favorecendo tanto a correção postural quanto a otimização da simetria muscular — aspectos cruciais no fisiculturismo.

Este trabalho tem como objetivo desenvolver um sistema de apoio ao fisiculturista, capaz de capturar imagens ou vídeos, identificar poses e oferecer correções automáticas relacionadas à postura e à simetria. Espera-se, com isso, demonstrar que a visão computacional pode ser uma aliada na busca pela excelência técnica do atleta, contribuindo tanto para o aperfeiçoamento em treinamentos quanto para a maior justiça em competições.

1.1 Motivação

O fisiculturismo vai além da estética: trata-se de uma prática que envolve disciplina, técnica e aperfeiçoamento contínuo. A correta execução das poses é fundamental não apenas para fins competitivos, mas também para o acompanhamento da evolução física e simetria do atleta. Contudo, a ausência de recursos tecnológicos acessíveis que auxiliem nessa avaliação dificulta o processo de aprendizado e aperfeiçoamento.

Enquanto em outros esportes já existem ferramentas digitais de monitoramento e análise de desempenho, no fisiculturismo o acompanhamento ainda depende fortemente da observação humana. Essa limitação restringe a autonomia do atleta, que muitas vezes só recebe *feedback* em treinos supervisionados ou em competições.

A possibilidade de empregar técnicas de visão computacional nesse contexto surge como um avanço significativo, oferecendo *feedback* objetivo, imediato e padronizado. Isso pode não apenas beneficiar atletas de alto rendimento, mas também amadores que buscam aperfeiçoar sua prática, democratizando o acesso a métodos de avaliação mais modernos e confiáveis.

1.2 Objetivos

1.2.1 Geral

Desenvolver um sistema de visão computacional para analisar poses de fisiculturismo e fornecer *feedback* automático em tempo real, auxiliando atletas na correção postural e no aperfeiçoamento técnico de seus treinos.

1.2.2 Específicos

- Pesquisar e compreender os fundamentos da visão computacional aplicados à detecção de poses humanas.
- Estudar Bibliotecas e *frameworks* adequados para implementação de pose estimation (*MediaPipe*).
- Implementar um sistema capaz de capturar imagens/vídeos e identificar os pontos-chave do corpo
- Integrar o sistema a uma interface visual com *feedback* em tempo real.

1.3 Resultados esperados

- Implementar um protótipo de sistema de visão computacional para análise de poses do fisiculturismo;
- Fornecer *feedback* automático em tempo real sobre postura e simetria;
- Validar a eficácia do sistema em auxiliar atletas no aperfeiçoamento técnico durante os treinos.

1.4 Estrutura do trabalho

Este trabalho está organizado como segue. No Capítulo 2 será apresentada a fundamentação teórica para o desenvolvimento do sistema, abordando conceitos do fisiculturismo e a importância da qualidade das poses, além dos fundamentos de visão computacional, técnicas de *pose estimation* e ferramentas utilizadas. O Capítulo 3 descreve a metodologia adotada, detalhando o ambiente de desenvolvimento, a arquitetura do sistema proposto, bem como a implementação do protótipo para análise de poses. O Capítulo 4 apresenta os resultados esperados, destacando a aplicabilidade do sistema e sua contribuição para o aperfeiçoamento técnico dos atletas. Por fim, no Capítulo 5, são apresentadas as considerações finais, ressaltando as contribuições do trabalho e sugerindo trabalhos futuros. Este trabalho também apresenta dois apêndices. O Apêndice A apresenta imagens de exemplo utilizadas nos testes do sistema, enquanto o Apêndice B apresenta o código-fonte desenvolvido em *Python* com as bibliotecas *MediaPipe* e *OpenCV*.

2 FUNDAMENTAÇÃO TEÓRICA

Para o desenvolvimento de um sistema de visão computacional voltado à análise de poses no fisiculturismo, é necessário compreender os conceitos que fundamentam esta proposta. Primeiramente, aborda-se o contexto do fisiculturismo e a importância da qualidade de pose. Em seguida, são apresentados os princípios da visão computacional, as técnicas de *pose estimation* e as ferramentas utilizadas, além de trabalhos relacionados que aplicam essas tecnologias em atividades físicas.

2.1 Fisiculturismo e Qualidade de Poses

O Fisiculturismo é um esporte que valoriza a simetria, a definição muscular e a execução correta de poses obrigatórias, fatores determinantes no desempenho competitivo dos atletas. Segundo Bompa e Cornacchia (2000), o fisiculturismo não se resume ao aumento da massa muscular, mas envolve também estratégias de apresentação corporal e técnicas de pose que destacam a estética e o equilíbrio físico. A apresentação em palco, portanto, exige que o atleta saiba demonstrar de forma controlada cada grupo muscular, o que faz da prática das poses uma parte fundamental do treinamento.

As poses clássicas, como o duplo bíceps, o peitoral de frente e o abdômen e coxas, são utilizadas como critérios de avaliação em competições oficiais (IFBB, 2023). A qualidade dessas poses influencia diretamente a pontuação do atleta, sendo analisadas a simetria, proporção, condicionamento físico e grau de definição muscular (SCHOENFELD, 2010).

Entretanto, a avaliação ainda depende fortemente da interpretação subjetiva de juízes e treinadores, o que pode levar a inconsistências nos resultados. Como destaca Bird (2018), a subjetividade na análise postural é um dos maiores desafios do fisiculturismo competitivo, pois abre margem para variações entre competições e julgadores. Assim, a busca por métodos mais objetivos e padronizados de avaliação representa um avanço significativo, beneficiando tanto atletas em treinos quanto profissionais envolvidos no acompanhamento esportivo.

2.1.1 Histórico do Fisiculturismo

O fisiculturismo, também chamado de *bodybuilding*, tem suas raízes no final do século XIX, o Pioneiro Eugen Sandow (1867-1925) é amplamente reconhecido como o “pai do fisiculturismo moderno”, por ter promovido exposições públicas de força e estética muscular, além de organizar em 1901, em Londres, a primeira grande competição oficial da modalidade, chamada *The Great Competition* (CHRISTOPHER, 2006). Sua imagem tornou-se tão influente que até hoje o troféu entregue aos campeões do *Mr. Olympia* carrega sua estátua em miniatura.

Na Figura 1, observa-se uma fotografia de Eugen Sandow, que demonstra o padrão estético valorizado na época, marcado pela simetria e pela apresentação muscular, elementos que fundamentam os critérios competitivos do fisiculturismo.

Figura 1 – Eugen Sandow




Fonte: Google Imagens

Nas décadas de 1930 e 1940, o fisiculturismo ganhou força com atletas como John Grimek, que uniu força e estética, sendo campeão do *Mr. American* em 1940 e 1941. Grimek é lembrado por elevar o padrão competitivo e inspirar gerações de atletas. Já nos anos 1950, o destaque foi Steve Reeves, campeão do *Mr. Universe* em 1950, que também se tornou astro de cinema, popularizando o físico atlético e estético para além das competições.

A Figura 2 apresenta John Grimek (a) e Steve Reeves (b), dois ícones que marcaram uma transição importante na modalidade. Enquanto Grimek simboliza a consolidação do fisiculturismo competitivo, Reeves projeta a imagem do fisiculturista

para o grande público, aproximando o esporte da cultura popular e reforçando o ideal de simetria e estética.

Figura 2 – (a) John Grimek (b) Steve Reeves



(a)

(b)

Fonte: Google Imagens

A década de 1960 marcou a ascensão de Larry Scott, primeiro campeão do *Mr. Olympia* em 1965, consolidando a competição criada pela IFBB (*International Federation of Bodybuilding and Fitness*). Scott ficou famoso por seus bíceps volumosos, apelidados de “*Scott’s Arms*”.

A Figura 3 ilustra Larry Scott (a) em uma de suas poses características, evidenciando o desenvolvimento muscular que o tornou um ícone da modalidade, e a logotipo oficial do *Mr. Olympia* (b), competição que se consolidou como a mais prestigiada do fisiculturismo mundial. A presença conjunta dessas imagens reforça a importância histórica de Scott na legitimação do campeonato e na definição de padrões estéticos que influenciam atletas até os dias atuais.

Figura 3 – (a)Larry Scott (b) Logo do Mr.Olympia



(a)

(b)

Fonte: Google Imagens

Nos anos 1970, o fisiculturismo atingiu um novo patamar de popularidade com Arnold Schwarzenegger, sete vezes campeão do *Mr. Olympia* (1970-1975; 1980), e Franco Columbu, seu contemporâneo e duas vezes campeão (1976, 1981). A dupla ficou eternizada no documentário *Pumping Iron* (1977), que contribuiu para difundir o fisiculturismo mundialmente e transformar Arnold em um ícone da cultura *pop*.

A Figura 4 apresenta Arnold Schwarzenegger (a) e Franco Columbu (b), dois dos principais representantes da chamada “Era de Ouro” do fisiculturismo. Enquanto Arnold simboliza o auge da estética clássica, com proporções imponentes e carisma que ultrapassaram os palcos, Franco exemplifica a densidade e o condicionamento muscular que complementavam a rivalidade e a amizade entre ambos. A representação conjunta desses atletas reforça o impacto cultural e esportivo desse período.

Figura 4 – (a) Arnold Schwarzenegger (b) Franco Columbu



(a)

(b)

Fonte: Google Imagens

Na década de 1980, surgiu Lee Haney, recordista de oito títulos consecutivos do *Mr. Olympia* (1984-1991), conhecido por sua simetria e proporção impecáveis. Esse recorde seria igualado posteriormente por Ronnie Coleman.

A Figura 5 mostra Lee Haney em pose de celebração, com a medalha do *Mr. Olympia* ao peito, simbolizando sua hegemonia na década de 1980. A imagem evidencia não apenas o volume muscular e a estética refinada que o consagraram, mas também a imponência de sua presença no palco, fatores que o transformaram em referência histórica e modelo de excelência para gerações seguintes de fisiculturistas.

Figura 5 – Lee Haney



Fonte: Google Imagens

Já nos anos 1990, o nome de Dorian Yates se destacou com seis títulos do *Mr. Olympia* (1992-1997), sendo pioneiro no estilo de treinamento de alta intensidade (*High Intensity Training*). Sua era abriu caminho para a ascensão de físicos cada vez mais volumosos, marcando o início de uma nova fase no fisiculturismo competitivo.

A Figura 6 apresenta Dorian Yates em uma de suas poses mais emblemáticas, evidenciando a densidade muscular, o condicionamento extremo e a musculatura dorsal que se tornaram suas marcas registradas. Sua aparência inovadora para a época consolidou o padrão de físicos “*mass monsters*”, influenciando diretamente os rumos da modalidade nas décadas seguintes.

Figura 6 – Dorian Yates



Fonte: Google Imagens

Na década de 2000, o destaque foi Ronnie Coleman, oito vezes campeão do *Mr. Olympia* (1998-2005). Considerado um dos maiores fisiculturistas da história, Coleman levou ao limite o conceito da “era dos gigantes”, exibindo um físico extremamente massivo aliado a condicionamento impressionante. Seu legado influenciou toda uma geração de atletas e consolidou os anos 2000 como um período em que o volume muscular atingiu níveis inéditos na modalidade.

A Figura 7 mostra Ronnie Coleman em uma de suas apresentações no palco do *Mr. Olympia*, representando a síntese máxima de volume e definição muscular já alcançados até então. A imagem transmite de forma clara a imponência física que o consagrou como ícone da “era *mass monster*”, consolidando seu nome na história do fisiculturismo.

Figura 7 – Ronnie Coleman



Fonte: Google Imagens

Na atualidade, o destaque vai para Chris Bumstead, campeão consecutivo da categoria *Classic Physique* do *Mr. Olympia* desde 2019. Bumstead simboliza a ascensão da *Classic Physique*, uma categoria criada para resgatar a estética clássica dos anos 1970, priorizando proporção, simetria e apresentação das poses, em contraste com a busca pelo volume extremo que marcou as décadas anteriores. Sua popularidade mundial, impulsionada também pelas redes sociais, consolidou uma nova fase do fisiculturismo, na qual a qualidade das poses voltou a ocupar posição central na avaliação dos atletas.

A Figura 8 mostra Chris Bumstead em uma de suas apresentações no *Mr. Olympia*, com foco em sua simetria e estética refinada. A imagem reforça a proposta da *Classic Physique* de resgatar o equilíbrio entre tamanho muscular e elegância das poses, destacando-o como representante máximo dessa nova era do fisiculturismo competitivo.

Figura 8 – Chris Bumstead



Fonte: Google Imagens

2.1.2 Poses Obrigatórias no Fisiculturismo

As poses obrigatórias representam a essência do julgamento competitivo no fisiculturismo, uma vez que permitem a comparação direta entre atletas sob critérios como simetria, proporção, volume muscular, definição, condicionamento e estética (IFBB, 2023). Diferentemente da simples exibição do físico, as poses exigem técnica, consciência corporal e prática contínua, já que pequenas falhas de alinhamento podem comprometer a apresentação e reduzir a pontuação.


A execução correta de cada pose é tão importante quanto o próprio desenvolvimento muscular, pois é nesse momento que o atleta “traduz” seu trabalho físico em estética visível para os juízes e para o público (SCHOENFELD, 2010). Muitos treinadores destacam que a arte do *posing* é um treino à parte, exigindo dedicação semelhante à musculação.

Entre as principais poses obrigatórias do *Bodybuilding Masculino* estão:

- Duplo Bíceps de Frente (*Front Double Biceps*): Evidencia braços, ombros, peitoral, quadríceps e abdômen. A simetria e a proporção entre membros superiores e inferiores são avaliadas nesta pose.
- Expansão de dorsais de Frente (*Front Lat Spread*): Demonstra a largura dorsal e a expansão torácica, destacando a forma em “V” do atleta.
- Expansão de dorsais de Costas (*Back Lat Spread*): Fundamental para avaliar dorsais, glúteo, posteriores de coxa e panturrilhas. É uma das poses que mais revelam a qualidade do condicionamento físico.
- Duplo Bíceps de Costas (*Back Double Biceps*): Permite observar definição dos braços, musculatura das costas e equilíbrio dos membros inferiores.
- Tríceps de Lado (*Side Triceps*): Destaca o tríceps, oblíquos e a densidade do peitoral. A postura do core é essencial para manter a linha estética.
- Peitoral de lado (*Side Chest*): Mostra o desenvolvimento dos peitorais, além do volume de braços e quadríceps.
- Abdômen e Coxa (*Abdominals and Thighs*): Evidencia a separação dos quadríceps e a definição abdominal. É decisiva para demonstrar condicionamento.
- Most Muscular (*Crab Pose* ou *Hands on Hips*): Considerada a pose de impacto, sintetiza volume, densidade e condicionamento muscular do atleta.

A Figura 9 ilustra Chris Bumstead executando o duplo bíceps de frente, exemplo clássico de como a pose evidencia braços, ombros, peitoral, quadríceps e abdômen em harmonia. Essa representação reforça a importância da técnica na tradução do desenvolvimento muscular em estética competitiva, valorizada tanto pelos juízes quanto pelo público.

Figura 9 – Chris Bumstead executando o duplo bíceps de frente.



Fonte: Google Imagens

Segundo Bird (2018), o domínio das poses é um fator que separa atletas medianos de campeões. Além disso, a prática do *posing* também ajuda no desenvolvimento do próprio físico, já que contrair intensamente os músculos durante os treinos de pose contribui para maior consciência corporal, melhora a vascularização e pode até auxiliar no ganho de resistência muscular localizada.

Essa ênfase na qualidade e precisão das poses conecta-se diretamente ao objetivo deste trabalho, uma vez que a utilização de sistemas de visão computacional pode auxiliar na detecção de falhas de postura, desalinhamentos e execução incorreta das poses, oferecendo ao atleta um retorno objetivo e em tempo real.

2.1.3 Critérios de Avaliação

O julgamento no fisiculturismo segue critérios técnicos definidos por federações como a IFBB (*International Federation of Bodybuilding and Fitness*), que estabelece parâmetros para analisar os atletas em competições oficiais. De modo geral, os principais pontos avaliados incluem:

- Simetria: Equilíbrio entre os lados direito e esquerdo do corpo, além da harmonia entre membros superiores e inferiores. Atletas com desequilíbrios visíveis tendem a perder pontos (IFBB, 2023).

- Proporção: Relação estética entre grupos musculares, evitando o desenvolvimento excessivo de uma parte do corpo em detrimento de outra (ARNOLD; DUBLIN, 2005).
- Volume Muscular: Tamanho e densidade dos músculos, evidenciados pelas poses obrigatórias.
- Definição e condicionamento: Grau de separação entre grupos musculares, vascularização e baixo percentual de gordura corporal (SCHOENFELD, 2010).
- Execução das poses: Postura, alinhamento, transições entre poses e capacidade de destacar os pontos fortes enquanto minimiza os fracos (BIRD, 2018).
- Apresentação cênica: Controle no palco, expressão corporal e confiança transmitida ao público e aos juízes (TAN, 2021).

Apesar desses parâmetros, a avaliação permanece subjetiva, pois depende da percepção individual dos juízes e pode variar de acordo com a experiência e preferências estéticas de cada avaliador. Como destaca Helms et al.(2019), essa subjetividade cria inconsistências entre competições, reforçando a necessidade de ferramentas tecnológicas que ofereçam medidas objetivas para auxiliar o julgamento e o acompanhamento do progresso dos atletas.

A Figura 10 apresenta os atletas Chris Bumstead e Ramon “Dino” Queiroz, durante a execução da pose de duplo bíceps de frente na categoria *Classic Physique* do Mr. Olympia 2023. Nesta comparação, nota-se que ambos exibem grande volume muscular e excelente condicionamento, mas com características distintas.

Figura 10 – Chris Bumstead (esquerda) e Ramon Dino (direita) executando a pose de duplo bíceps de frente no Mr. Olympia, 2023.



Fonte: Google Imagens

Bumstead evidencia maior largura de dorsais e uma forma em “V” mais acentuada, reforçando a simetria entre membros superiores e inferiores, além de transmitir maior equilíbrio estético no alinhamento da pose. Já Ramon apresenta um abdômen mais detalhado e quadríceps com maior separação muscular, o que destaca seu condicionamento de membros inferiores e a densidade muscular do tronco.

Essa análise demonstra como, mesmo em atletas de elite, a interpretação dos critérios pode variar: Enquanto um apresenta maior proporção estética global, o outro ressalta definição e impacto visual em áreas específicas. Tal subjetividade reforça a importância da adoção de ferramentas tecnológicas que possam oferecer uma avaliação padronizada e objetiva das poses.

2.1.4 Importância da Qualidade das Poses nos Treinos

O treinamento de poses (*posing practice*) é considerado uma das etapas mais importantes da preparação no fisiculturismo competitivo. Embora muitas vezes seja negligenciado por atletas iniciantes, profissionais de alto nível reconhecem que dominar as poses pode ser tão decisivo quanto a hipertrofia muscular em si (SANTANA; VIEIRA, 2019).

Durante a execução das poses obrigatórias, o atleta desenvolve consciência corporal, controle motor fino e capacidade de contração voluntária máxima. Esse processo aprimora a habilidade de destacar grupos musculares específicos enquanto mantém a simetria e a proporção global. Segundo Hackett, Johnson e Chow (2013), o treinamento de poses pode ser comparado a um exercício isométrico de alta intensidade, promovendo melhora no condicionamento muscular e cardiovascular.

A Figura 11 apresenta Chris Bumstead treinando poses em sua academia privada, exemplificando como até mesmo atletas consagrados dedicam parte significativa de sua preparação a essa prática. A imagem reforça a ideia de que o *posing* não é apenas uma formalidade competitiva, mas um treino fundamental para aperfeiçoar a apresentação física no palco.

Figura 11 – Chris Bumstead treinando pose em sua academia privada.



Fonte: Pinterest

Além disso, o *posing* atua como uma ferramenta de *feedback* visual. Ao praticar em frente a espelhos ou sob diferentes condições de iluminação, atletas e treinadores conseguem avaliar pontos fortes e fracos do físico, possibilitando ajustes no treino e na dieta (SCHOENFELD, 2010). Essa prática auxilia na detecção de desequilíbrios posturais, assimetrias e na melhoria do condicionamento cênico, aspectos frequentemente determinantes no julgamento final (IFBB, 2023).

A Figura 12 ilustra o contraste físico do atleta Jay Cutler, mostrando-o (a) fora de temporada de dieta e (b) em plena preparação competitiva no Mr. Olympia 2009. Essa comparação evidencia como o processo de ajustes alimentares e de treino é determinante para alcançar o condicionamento extremo exigido nos palcos, ressaltando a importância da disciplina contínua no fisiculturismo.

Figura 12 – Jay Cutler (a) fora de temporada de dieta e (b) competindo no Mr. Olympia 2009.



(a)

(b)

Fonte: Google Imagens

Outro fator relevante é a resistência psicológica adquirida durante o treino de poses. Manter contrações intensas por períodos prolongados exige não apenas condicionamento físico, mas também foco mental e tolerância ao desconforto, qualidades cruciais em apresentações competitivas (HELMS et al., 2019).

A Figura 13 exemplifica esse processo ao mostrar André “Pajé” Pierin e Fabrício Pacholok auxiliando Ramon Dino no ajuste de poses. A cena evidencia como o suporte técnico durante o treino contribui não apenas para o refinamento da postura, mas também para o desenvolvimento da resistência mental necessária para sustentar contrações intensas, lidar com o desconforto e manter a precisão das poses exigidas em contextos competitivos.

Figura 13 – André “Pajé” Pierin e Fabrício Pacholok auxiliando Ramon Dino no ajuste de poses.



Fonte: Canal “Max Titanium”, Youtube

Portanto, a qualidade do *posing* não deve ser vista como um complemento, mas como parte intrínseca da preparação esportiva no fisiculturismo. A correta execução das poses potencializa o impacto visual de um físico bem condicionado e pode representar a diferença entre o pódio e a eliminação precoce. Dessa forma, o *posing* se consolida como parte essencial da preparação competitiva, atuando tanto no condicionamento físico e mental quanto na apresentação estética, sendo determinante para o sucesso no palco.

2.1.5 Limitações da Avaliação Subjetiva

O julgamento no fisiculturismo, embora baseado em critérios técnicos previamente definidos, mantém um elevado grau de subjetividade. Isso ocorre porque fatores como percepção individual, preferências estéticas e até a experiência prévia dos árbitros podem influenciar diretamente a pontuação atribuída (HELMS et al., 2019)

Segundo Bird (2018), mesmo com parâmetros claros - simetria, proporção, volume e definição muscular - a avaliação varia entre competições e federações, já que cada juiz pode valorizar aspectos diferentes do físico do atleta. Esse cenário gera questionamentos frequentes quanto à consistência e transparência dos resultados.

Outro ponto crítico é a influência de fatores externos, como iluminação do palco, posição dos atletas na fila de apresentação e tempo de execução das poses, que podem favorecer ou prejudicar a percepção visual do corpo. Além disso, em competições de alto nível, onde os atletas apresentam físicos muito próximos em qualidade, detalhes mínimos acabam decidindo os resultados, ampliando a margem de interpretação subjetiva (SANTANA; VIEIRA, 2019).

Essas limitações apontam para a necessidade de ferramentas complementares que tragam objetividade e padronização ao processo de avaliação. Tecnologias de visão computacional e análise de poses surgem como soluções promissoras, capazes de fornecer métricas quantitativas sobre simetria, ângulos articulares, proporções e condicionamento muscular, auxiliando tanto árbitro quanto atletas no acompanhamento do desempenho.

2.2 Visão Computacional

A visão computacional é uma das áreas mais dinâmicas da inteligência artificial, tendo como objetivo permitir que computadores capturem, processem e interpretem informações visuais de forma semelhante ao sistema de percepção humano. Sua aplicação em diferentes setores mostra o potencial transformador dessa tecnologia, que tem avançado em paralelo ao aumento do poder computacional e ao desenvolvimento de algoritmos de aprendizado profundo.

2.2.1 Conceitos Fundamentais

A visão computacional pode ser definida como o campo da ciência da computação que busca compreender imagens e vídeos de maneira automática, extraindo informações relevantes e transformando dados visuais em conhecimento estruturado (FORSYTH; PONCE, 2012). Diferente do processamento de imagens, que foca em técnicas de manipulação e melhoria de qualidade visual, a visão computacional está voltada à interpretação semântica das imagens, ou seja, entender o que está sendo apresentado.

Segundo Prince (2012), a visão computacional integra três pilares:

1. Aquisição: Captura de dados por meio de sensores, câmeras ou dispositivos ópticos;

2. Processamento: Aplicação de algoritmos de segmentação, extração de características e aprendizado de máquina;
3. Interpretação: Transformação dos dados em decisões ou ações automatizadas.

Um dos maiores diferenciais da visão computacional em relação à percepção humana é sua objetividade e reprodutibilidade. Enquanto os humanos estão sujeitos a vieses cognitivos e limitações fisiológicas, os algoritmos podem analisar dados visuais de forma padronizada e com precisão matemática (JAIN; FLYNN; ROSS, 2007). Essa característica se torna especialmente relevante em cenários que exigem justiça e consistência, como o julgamento em competições esportivas.

Além disso, a visão computacional é frequentemente associada a outras áreas, como inteligência artificial, reconhecimento de padrões e aprendizado profundo, ampliando suas aplicações. De acordo com Gonzalez e Woods (2018), essa interdisciplinaridade é o que permite a construção de sistemas capazes de identificar rostos, analisar poses humanas, interpretar imagens médicas e até mesmo conduzir veículos autônomos.

Em resumo, a visão computacional representa a transição do simples processamento de pixels para a compreensão do significado das imagens, posicionando-se como uma ferramenta poderosa em áreas que demandam análise visual precisa e objetiva.

2.2.2 Evolução Histórica

O desenvolvimento da visão computacional acompanha a própria evolução da ciência da computação. Seus primeiros registros datam da década de 1960, quando pesquisadores buscavam compreender como computadores poderiam simular processos perceptivos do olho humano. Os experimentos iniciais envolviam reconhecimento de caracteres, identificação de formas geométricas simples e interpretação de imagens bidimensionais em preto e branco (BALLARD; BROWN, 1982).

Na década de 1970, o foco voltou-se para problemas como segmentação de imagens e detecção de bordas, com algoritmos clássicos como os de Roberts, Sobel e Canny, que permanecem relevantes até hoje em tarefas básicas de

pré-processamento (FORSYTH;PONCE, 2012). Esse período marcou a consolidação da visão computacional como disciplina independente dentro da ciência da computação.

Já nos anos 1980 e 1990, a expansão da capacidade computacional e o surgimento de bancos de dados visuais impulsionam pesquisas em reconhecimento de objetos e visão estereoscópica. Métodos baseados em estatística e aprendizado supervisionado começaram a ser aplicados, ainda que de forma limitada pela restrição de *hardware* disponível na época (PRINCE, 2012).

O início dos anos 2000 foi marcado pelo avanço dos algoritmos de aprendizado de máquina, em especial *Support Vector Machines* (SVM), que possibilitaram melhorias significativas no reconhecimento de padrões visuais. Entretanto, a grande revolução ocorreu a partir de 2012, com o trabalho de Krizhevsky, Sutskever e Hinton, que apresentou a rede neural convolucional AlexNet, vencedora da competição ImageNet. Esse marco consolidou o *deep learning* como paradigma dominante, elevando a precisão em tarefas de classificação e detecção de imagens a níveis superiores aos da percepção humana em alguns cenários (SZELISKI, 2022).

Na Atualidade, a visão computacional está fortemente associada a arquiteturas avançadas como *ResNet*, *YOLO* e *Transformers* visuais (ViT), permitindo aplicações em larga escala que vão desde veículos autônomos até diagnósticos médicos assistidos por inteligência artificial (REDMON; FARHADI, 2018; DOSOVITSKIY et al., 2021). Essa trajetória histórica demonstra como a área evolui de experimentos rudimentares para sistemas complexos capazes de transformar práticas em setores estratégicos da sociedade.

2.2.3 Principais Aplicações


A visão computacional, ao longo das últimas décadas, consolidou-se como uma das áreas mais promissoras da inteligência artificial, com aplicações práticas em diversos setores da sociedade. Sua relevância está diretamente associada à capacidade de processar grandes volumes de dados visuais e transformá-los em informações úteis para tomada de decisão.

Na área da saúde, técnicas de visão computacional são amplamente utilizadas em sistemas de auxílio ao diagnóstico médico, como a detecção de

tumores em exames de ressonância magnética, a análise de radiografias e a identificação precoce de doenças oculares (LITJENS et al., 2017). Esses métodos contribuem para diagnósticos mais rápidos e precisos, reduzindo a carga de trabalho de especialistas.

A Figura 14 apresenta um exemplo de aplicação prática da visão computacional na detecção de tumores cerebrais por meio de exames de ressonância magnética. Observa-se que o sistema é capaz de realçar regiões suspeitas automaticamente, auxiliando médicos na identificação de anomalias com maior rapidez e confiabilidade. Esse tipo de abordagem evidencia como a tecnologia pode atuar de forma complementar ao trabalho humano, garantindo maior eficiência no diagnóstico clínico.

Figura 14 – Exemplo de aplicação de visão computacional na área médica - Detecção de tumor em ressonância magnética.




Fonte: EINSTEIN (São Paulo).

Na área de segurança, a tecnologia é aplicada em sistemas de monitoramento e vigilância inteligente, com destaque para o reconhecimento facial em tempo real e a análise de padrões de comportamento em grandes multidões (ZHAO et al., 2003). Além disso, soluções de autenticação biométrica baseadas em visão computacional têm sido implementadas em aeroportos e serviços financeiros, reforçando a confiabilidade de processos de identificação.

A Figura 15 ilustra um sistema de vigilância baseado em visão computacional que utiliza *bounding boxes* para identificar e rastrear veículos em uma via urbana. Essa técnica permite a detecção automática de diferentes categorias, como carros e motocicletas, possibilitando o monitoramento do tráfego, a prevenção de crimes e a

análise de fluxo em tempo real. Esse tipo de aplicação reforça o papel da visão computacional na segurança pública e no gerenciamento inteligente das cidades.

Figura 15 – Sistema de vigilância com *bounding boxes*.




Fonte: Google Imagens.

No setor industrial, a visão computacional atua principalmente no controle de qualidade em linhas de produção, detectando defeitos em peças e embalagens, além de otimizar processos de logística e automação (SZELISKI, 2022). Esse uso tem se mostrado fundamental na chamada Indústria 4.0, onde eficiência e precisão são fatores determinantes para a competitividade.

A Figura 16 exemplifica a aplicação dessa tecnologia em uma linha de produção automatizada, onde sistemas de inspeção visual identificam defeitos em tampas de garrafas antes de serem embaladas. Esse tipo de solução permite reduzir perdas, aumentar a confiabilidade dos produtos e garantir maior padronização na produção, destacando a relevância da visão computacional para a indústria moderna.

Figura 16 – Inspeção automatizada de peças/embalagens em linhas de produção.



Fonte: Google Imagens

Nos esportes, os avanços da visão computacional possibilitam a análise do movimento humano, contribuindo para a melhoria do desempenho atlético e a prevenção de lesões (WU et al., 2021). Ferramentas baseadas em *pose estimation* permitem acompanhar padrões biomecânicos, avaliar a técnica de execução e fornecer *feedback* em tempo real. Nesse contexto, abre-se espaço para aplicações no fisiculturismo, em que a correta execução e qualidade das poses são determinantes para o sucesso competitivo. Sistemas desse tipo podem auxiliar atletas na preparação e oferecer métricas objetivas para complementar a avaliação dos árbitros.

A Figura 17 exemplifica essa aplicação ao mostrar um atleta com o esqueleto digital sobreposto ao corpo por meio de *pose estimation*. Esse recurso possibilita identificar o alinhamento de articulações e a amplitude dos movimentos, favorecendo correções imediatas e uma análise biomecânica precisa, que pode ser decisiva tanto para a prevenção de lesões quanto para o refinamento da performance em competições.

Figura 17 – *Pose Estimation* com esqueleto sobreposto a um atleta.



Fonte: Google Imagens

Assim, a diversidade de aplicações da visão computacional demonstra sua versatilidade e reforça seu potencial como ferramenta estratégica em áreas críticas e de alto impacto social, incluindo o aperfeiçoamento técnico no fisiculturismo, tema central deste trabalho.

2.2.4 Relevância para o Fisiculturismo

O fisiculturismo é um esporte cuja avaliação depende de parâmetros como simetria, proporção, definição e qualidade de execução das poses, mas que ainda se apoia em um processo altamente subjetivo (HELMS et al., 2019; SANTANA; VIEIRA, 2019). Nesse cenário, a visão computacional surge como uma ferramenta inovadora, capaz de oferecer métricas objetivas e complementares ao julgamento humano.

Por meio de técnicas de *pose estimation*, é possível mapear pontos articulares do corpo humano e transformá-los em dados quantitativos, como ângulos, alinhamentos e proporções (WU et al., 2021). Esses recursos permitem comparar atletas com maior precisão, identificar desequilíbrios corporais e fornecer *feedback* imediato durante os treinos. Além disso, o uso de métricas automatizadas pode aumentar a transparência e consistência nos julgamentos em competições oficiais, reduzindo a influência de vieses individuais (ZHAO et al., 2003).

A aplicação dessa tecnologia no fisiculturismo também abre caminho para o acompanhamento da evolução atlética. Sistemas baseados em visão computacional podem registrar a progressão do físico ao longo do tempo, comparando fotografias ou vídeos de diferentes fases de preparação, o que auxilia no planejamento de treinos e na estratégia competitiva (LITJENS et al., 2017; SZELISKI, 2022).

A Figura 17 exemplifica a utilização de algoritmos de *pose estimation*, onde linhas e pontos articulados são sobrepostos ao corpo de um atleta. Essa abordagem ilustra como a visão computacional pode capturar informações biomecânicas essenciais para avaliar a qualidade e a precisão das poses, reforçando a conexão entre a teoria apresentada neste capítulo e a proposta prática do presente trabalho.

2.3 Pose Estimation

A *pose estimation* (ou estimativa de pose humana) é uma técnica da visão computacional voltada para a identificação e o rastreamento da posição de partes do

corpo em imagens ou vídeos. Seu objetivo é detectar pontos de referência anatômicos - denominados *keypoints* - como cabeça, ombros, cotovelos, joelhos e tornozelos, a fim de modelar a postura de um indivíduo em tempo real ou em registros estáticos (ZHENG et al., 2020).

Essa abordagem ganhou relevância nos últimos anos devido à evolução de métodos de aprendizado profundo, que possibilitam avanços significativos em termos de precisão, velocidade e robustez em cenários complexos. Atualmente, bibliotecas como *OpenPose* (Cao et al., 2017) e *MediaPipe* (LUGARES et al., 2020) tornaram-se referências no campo, com aplicações que vão desde análise esportiva até realidade aumentada.

2.3.1 Conceitos e Métodos

Os métodos de *pose estimation* podem ser classificados em dois grandes grupos:

1. Estimativa 2D: Identifica a posição dos pontos-chave em duas dimensões, suficiente para análise de poses em imagens estáticas ou vídeos convencionais.
2. Estimativa 3D: Adiciona profundidade, permitindo reconstruções corporais mais realistas e detalhadas.

Segundo Szeliski (2022), os métodos modernos geralmente utilizam redes neurais convolucionais (CNNs) para localizar articulações em mapas de calor (*heatmaps*), que indicam a probabilidade de cada ponto estar em determinada posição. Entre os algoritmos mais conhecidos destacam-se:

- *OpenPose*: Pioneiro na detecção de múltiplas pessoas e pontos-chave de corpo, rosto e mãos em tempo real (CAO et al., 2017).
- *MediaPipe Pose*: Desenvolvido pelo Google, fornece uma solução rápida e eficiente para dispositivos móveis e aplicações interativas (LUGARES et al., 2020).
- *DensePose*: Permite mapear cada pixel da imagem em uma superfície 3D do corpo humano (GÜLER et al., 2018).

2.3.2 Extração de Pontos-Chave

A etapa central da *pose estimation* é a extração dos *keypoints*, que representam as articulações principais do corpo. Normalmente são utilizados de 17 a 33 pontos, dependendo do modelo adotado.

Esses pontos permitem calcular métricas como:

- Ângulos articulares (Ex: Flexão de cotovelo, extensão do joelho);
- Simetria Corporal (Comparação entre os lados esquerdo e direito);
- Proporções entre membros;
- Trajetória do movimento ao longo do tempo.

Segundo Zheng et al. (2020), a análise desses dados é o que torna a *pose estimation* útil para aplicações em biomecânica, reabilitação física, ergonomia e esportes de performance.

2.3.3 Aplicações em Esportes e Correção Postural

No contexto esportivo, a *pose estimation* vem sendo empregada para analisar o desempenho atlético, prevenir lesões e otimizar a execução de movimentos. Em modalidades como corrida, natação e levantamento de peso, sistemas baseados nessa tecnologia permitem identificar falhas técnicas e fornecer *feedback* imediato para treinadores e atletas (WU et al., 2021).

Na correção postural, a tecnologia é utilizada em programas de fisioterapia e em aplicações de *fitness* digital, auxiliando usuários a executarem exercícios corretamente em academias virtuais e aplicativos móveis (ZHENG et al., 2020).

No fisiculturismo, a aplicação da *pose estimation* é particularmente promissora, uma vez que possibilita avaliar objetivamente a qualidade das poses obrigatórias e comparar dados entre atletas. Essa abordagem pode complementar o julgamento humano, reduzindo a subjetividade do processo e oferecendo aos competidores uma ferramenta de acompanhamento de progresso técnico.

A Figura 17 apresenta um exemplo de *pose estimation*, onde pontos-chave e conexões são sobrepostos ao corpo de um atleta durante a execução de uma pose. Esse tipo de visualização ilustra como a tecnologia pode capturar informações biomecânicas relevantes e aplicá-las diretamente ao contexto do fisiculturismo.

3 SISTEMA DE ANÁLISE DE POSE

Este capítulo descreve a metodologia adotada para o desenvolvimento do sistema proposto, detalhando desde o ambiente utilizado até a implementação prática da solução. Na Seção 3.1, é apresentado o ambiente de desenvolvimento, incluindo *hardware*, *software* e linguagens empregadas. A Seção 3.2 aborda a arquitetura do sistema, destacando os módulos de captura, processamento, análise e saída de resultados. Em seguida, a Seção 3.3 apresenta a implementação do protótipo, descrevendo os procedimentos realizados para a detecção e análise das poses. A Seção 3.4 detalha as ferramentas e bibliotecas utilizadas, com ênfase nas soluções de visão computacional *MediaPipe* e *OpenCV*. Por fim, a Seção 3.5 apresenta os trabalhos relacionados, ressaltando pesquisas e aplicações semelhantes no contexto esportivo e de correção postural, situando este estudo no panorama científico atual.

3.1 Ambiente de Desenvolvimento

O desenvolvimento do sistema foi realizado em um ambiente configurado para atender às demandas de visão computacional em tempo real, integrando *hardware* robusto, bibliotecas de inteligência artificial e boas práticas de programação para garantir eficiência e escalabilidade.

O hardware utilizado consistiu em um computador com processador *Intel Core i5* de 11ª geração, 16 GB de memória RAM e placa gráfica NVIDIA *GeForce GTX 1660* (6 GB VRAM), que possibilitou a aceleração de operações em GPU. O sistema operacional adotado foi o Windows 11 Pro (64 bits), garantindo compatibilidade com bibliotecas e *frameworks* amplamente empregados em projetos de visão computacional.

Para o ambiente de programação, utilizou-se o *Python 3.10*, consolidado na área por sua flexibilidade e amplo ecossistema de bibliotecas. O gerenciamento de dependências foi realizado via *Anaconda Distribution*, permitindo a criação de ambientes virtuais isolados. As principais ferramentas utilizadas foram o *Visual Studio Code*, empregado na organização modular do código e integração com o

GitHub, e o *Jupyter Notebook*, explorado para prototipação rápida e testes incrementais dos algoritmos de análise de pose.

O protótipo fez uso das seguintes bibliotecas principais:

- *OpenCV*: responsável pela captura de vídeo, manipulação e pré-processamento de imagens em tempo real;
- *MediaPipe*: utilizada para a extração de pontos-chave (landmarks) corporais e construção do esqueleto digital;
- *NumPy* e *Pandas*: para manipulação e organização de dados numéricos;
- *Matplotlib*: para a visualização gráfica dos resultados intermediários.

Além do suporte básico, foram aplicados procedimentos específicos de desenvolvimento:

- Implementação de funções para cálculo de ângulos articulares (por exemplo, cotovelo em relação ao ombro e punho), viabilizando a análise da execução das poses;
- Definição de limiares de tolerância para avaliar a correção ou não da postura, levando em consideração diferenças entre indivíduos;
- Estratégias de *feedback* visual no ambiente de execução, como mensagens sobre a imagem (“cotovelo baixo”, “simetria correta”) e coloração diferenciada nas conexões do esqueleto;
- Tratamento de exceções, como ausência de pontos-chave detectados pelo *MediaPipe*, perda de enquadramento da câmera ou falhas momentâneas de iluminação.

Esse conjunto de recursos de *hardware*, *software* e práticas de programação garantiu um ambiente adequado não apenas para o desenvolvimento do protótipo, mas também para futuras expansões, como inclusão de métricas adicionais (simetria global, proporção entre membros) e integração com bancos de dados para análise comparativa de atletas.

3.2 Arquitetura do Sistema

A arquitetura do sistema foi projetada de forma modular, visando simplicidade, escalabilidade e clareza na organização dos processos. O sistema segue um fluxo

sequencial composto por quatro camadas principais: aquisição de dados, processamento de imagem, análise de pose e feedback visual.

- Aquisição de dados
 - Responsável pela captura contínua de vídeo via *webcam* ou câmera externa.
 - Implementada com a biblioteca *OpenCV*, que realiza a leitura de *frames* em tempo real.
 - Inclui verificações para garantir a taxa mínima de quadros por segundo (FPS) necessária para evitar atrasos no processamento.
- Processamento de imagem
 - Cada *frame* capturado é tratado para conversão de cores (BGR para RGB), padronização de tamanho e otimização da entrada para o modelo de *pose estimation*.
 - Essa etapa garante que o *MediaPipe* receba dados consistentes para detecção.
- Análise de pose
 - Utiliza o modelo *MediaPipe Pose*, que detecta até 33 pontos-chave (*landmarks*) do corpo humano.
 - A partir desses pontos, o sistema implementa funções para cálculo de ângulos articulares, como cotovelo, ombro e joelho.
 - Inclui regras pré-definidas para avaliar poses específicas do fisiculturismo, como o duplo bíceps de frente, verificando simetria entre membros e alinhamento com os ombros.
- *Feedback* visual
 - Sobreposição do esqueleto digital diretamente sobre o vídeo do atleta.
 - Exibição de mensagens corretivas na tela, indicando, por exemplo: “braços desalinhados”, “cotovelos abaixo da linha dos ombros” ou “pose correta”.
 - Esse retorno em tempo real oferece ao atleta um recurso de autocorreção durante os treinos, sem a necessidade de intervenção imediata de um treinador.

Essa arquitetura modular foi planejada para permitir futuras expansões, como inclusão de novas poses obrigatórias, análise comparativa entre atletas e integração com bancos de dados históricos para acompanhamento da evolução individual.

3.3 Implementação do Código

O protótipo foi desenvolvido em *Python*, estruturado de forma a integrar as bibliotecas *OpenCV* e *MediaPipe* para realizar a análise de poses em tempo real. O código segue uma arquitetura modular, composta por funções que lidam com captura de vídeo, processamento, cálculo de ângulos e exibição do *feedback* visual.

O sistema é inicializado com a configuração do modelo de pose fornecido pelo *MediaPipe*. Para cada *frame* capturado pela *webcam*, ocorre a conversão do espaço de cores de BGR para RGB, assegurando a compatibilidade com o modelo de detecção. Esse fluxo contínuo é controlado por um laço de repetição (*loop*), que só é encerrado quando o usuário decide finalizar a execução.

Após o pré-processamento, o *MediaPipe Pose* identifica os 33 pontos-chave (*landmarks*) do corpo humano. No código, esses pontos são armazenados em uma estrutura que permite calcular ângulos articulares específicos, como o alinhamento entre ombro, cotovelo e punho na execução de poses de braços. O cálculo dos ângulos utiliza operações vetoriais com base no produto escalar, uma abordagem matemática eficiente para determinar a relação entre segmentos do corpo.


Além da análise geométrica, o sistema implementa funções de verificação de simetria. Essas funções comparam os valores dos ângulos do lado esquerdo e direito do corpo, emitindo mensagens de correção quando diferenças significativas são detectadas. Por exemplo, se um cotovelo estiver mais baixo que o outro em um duplo bíceps, o sistema sinaliza a necessidade de ajuste.

O *feedback* visual é realizado por meio da sobreposição de informações diretamente no *frame*. O código utiliza o *OpenCV* para:

- Desenhar o esqueleto digital, conectando os pontos detectados.
- Exibir os valores dos ângulos próximos às articulações.
- Mostrar mensagens de orientação na tela, como “corrigir alinhamento” ou “pose correta”.

A Figura 18 apresenta o fluxo de execução do sistema, evidenciando de forma clara as etapas que vão desde a inicialização do modelo de pose até o processamento contínuo dos *frames*, incluindo detecção de *landmarks*, cálculo de ângulos, verificação das condições de avaliação e geração do feedback visual.


Figura 18 – Fluxograma da execução do sistema.



Fonte: Elaborado pelo autor

A Figura 19 apresenta a execução prática do sistema, evidenciando o esqueleto digital sobreposto ao corpo e a marcação de ângulos articulares, que permitem identificar possíveis desvios posturais em tempo real.

Figura 19 – Execução do sistema com sobreposição do esqueleto e ângulos articulares.



(a)

(b)

Fonte: Elaborado pelo autor

Essa implementação garante que o sistema funcione como uma ferramenta de treinamento assistido, fornecendo correções imediatas. O código também foi estruturado para permitir expansão futura, como a inclusão de novas poses obrigatórias do fisiculturismo ou a integração com métodos de aprendizado profundo para maior precisão.

3.4 Ferramentas e Bibliotecas Utilizadas

O sistema foi construído com base em um conjunto de bibliotecas e ferramentas que fornecem suporte tanto ao processamento de imagens quanto à análise geométrica das poses. A escolha dessas tecnologias levou em consideração critérios como desempenho, flexibilidade, documentação e comunidade de suporte.

A linguagem *Python* foi selecionada por sua ampla adoção em projetos de inteligência artificial e visão computacional, além da vasta disponibilidade de bibliotecas otimizadas para tarefas científicas. Entre essas bibliotecas, destaca-se a *OpenCV*, que atua como base para a captura de vídeo, manipulação de quadros e inserção de elementos gráficos.

A detecção dos pontos-chave do corpo humano foi realizada com a biblioteca *MediaPipe*, que disponibiliza modelos de aprendizado de máquina pré-treinados para reconhecimento de estruturas corporais. Essa escolha se justifica pela eficiência computacional da biblioteca, que possibilita análises em tempo real sem necessidade de *hardware* especializado de alto custo.

No tratamento matemático, foi utilizada a biblioteca *NumPy*, essencial para cálculos vetoriais e operações matriciais, que permitiram implementar de forma

eficiente a extração de ângulos articulares e métricas de simetria corporal. Complementarmente, a biblioteca *Matplotlib* foi utilizada durante o processo de validação e testes, possibilitando a visualização gráfica dos dados e facilitando a etapa de depuração.

Dessa forma, a combinação dessas ferramentas garantiu ao sistema não apenas a capacidade de processar imagens em tempo real, mas também a flexibilidade necessária para futuras expansões, como a inclusão de novos modelos de análise e de métricas específicas para o fisiculturismo.

3.5 Trabalhos Relacionados

O uso de visão computacional em contextos esportivos tem crescido significativamente, especialmente com a popularização de técnicas de pose estimation. Diversos estudos têm demonstrado como essa abordagem pode auxiliar no monitoramento biomecânico, na correção de movimentos e na prevenção de lesões. Hackett, Johnson e Chow (2013), por exemplo, discutem o uso de práticas de treinamento e tecnologias digitais aplicadas ao fisiculturismo, reforçando a necessidade de ferramentas que auxiliem na análise da execução técnica.

Em modalidades distintas, como yoga e dança, sistemas baseados em *MediaPipe* e *OpenPose* já foram aplicados com sucesso, oferecendo *feedback* em tempo real sobre o alinhamento postural dos praticantes (SANTANA; VIEIRA, 2019). Esses trabalhos evidenciam que a visão computacional pode desempenhar papel relevante em atividades que exigem precisão gestual, ainda que a área específica do fisiculturismo permaneça pouco explorada.

Pesquisas mais recentes também destacam o uso da pose estimation em esportes de alta intensidade, como corrida e artes marciais, demonstrando ganhos na análise da técnica e na avaliação da eficiência dos movimentos (HELMS; ARAGON; FITT, 2019). Essas iniciativas confirmam a aplicabilidade da visão computacional como suporte a treinadores e atletas, mas deixam clara a lacuna existente quanto à avaliação objetiva das poses do fisiculturismo, que até o momento ainda depende majoritariamente da percepção subjetiva de juízes.

Assim, este trabalho se diferencia por buscar aplicar a visão computacional diretamente no contexto competitivo do fisiculturismo, oferecendo uma ferramenta inovadora para análise postural e simétrica dos atletas, com potencial de

contribuição tanto no ambiente de treino quanto em avaliações formais.

4 RESULTADOS

O protótipo foi executado em tempo real a partir da captura de vídeo pela *webcam*, demonstrando capacidade de detectar pontos-chave corporais, projetar o esqueleto digital sobre a imagem do atleta e emitir mensagens automáticas de correção referentes à simetria dos braços na pose de duplo bíceps de frente, amplamente utilizada no fisiculturismo competitivo.

Durante os testes, observou-se que a ferramenta conseguiu manter a taxa média de processamento em aproximadamente 21 quadros por segundo (FPS), garantindo *feedback* imediato ao usuário. O sistema destaca os ângulos formados pelos membros superiores e verifica a simetria entre o braço direito e o esquerdo. Quando a postura se encontra dentro dos parâmetros definidos, surge a mensagem “Posição correta – Excelente postura!”, conforme ilustrado na Figura 19.


Figura 20 – Protótipo avaliando a pose de duplo bíceps corretamente.



Fonte: Elaborado pelo autor

Por outro lado, quando a postura apresenta desalinhamentos significativos — como cotovelos projetados para baixo ou diferença de altura entre os braços — o sistema emite alertas corretivos, sinalizando ao atleta a necessidade de ajuste imediato. Esse processo pode ser observado na Figura 20, em que ambos os cotovelos foram identificados como “muito baixos”, resultando na mensagem em vermelho: “Posição incorreta – Cotovelo esquerdo muito baixo; Cotovelo direito muito baixo.”.

Figura 21 – Protótipo identificando execução incorreta da pose de duplo bíceps.



Fonte: Elaborado pelo autor

A comparação entre as Figuras 19 e 20 evidencia a eficácia do sistema em diferenciar posturas corretas e incorretas, reforçando sua aplicabilidade prática como ferramenta de apoio no treino de fisiculturistas. Ao oferecer avaliação objetiva e instantânea, o protótipo contribui para reduzir a subjetividade do julgamento individual e auxilia o atleta no aprimoramento técnico de poses específicas.

Durante os testes, verificou-se também que o uso de diferentes tipos de roupas não interferiu na precisão das análises, pois o MediaPipe realiza a detecção de *landmarks* com base na estrutura corporal e não em características visuais da vestimenta, permitindo avaliar a postura de forma consistente mesmo com tecidos, cores ou formatos variados. Além disso, o sistema manteve desempenho estável em condições distintas de iluminação, seja em ambientes mais claros, mais escuros ou com tonalidades variadas, demonstrando robustez na identificação dos pontos-chave. Da mesma forma, mudanças na distância entre o atleta e a câmera não comprometeram a acurácia da detecção, evidenciando que o protótipo apresenta confiabilidade tanto em cenários controlados quanto em condições reais de uso.

5 CONCLUSÃO

O desenvolvimento do protótipo apresentado neste trabalho evidenciou o potencial da visão computacional como ferramenta de apoio no fisiculturismo, uma modalidade que exige elevada precisão na execução de poses e na simetria corporal. A aplicação de técnicas de pose estimation permitiu a detecção em tempo real de pontos-chave do corpo humano, possibilitando a avaliação automática da postura durante a execução da pose de duplo bíceps de frente.

Os resultados obtidos demonstraram que o sistema foi capaz de reconhecer posturas corretas e identificar falhas de alinhamento, fornecendo *feedback* imediato ao atleta. Essa funcionalidade representa um avanço significativo em relação ao modelo tradicional de análise, que ainda depende fortemente da experiência subjetiva de treinadores e juízes. Ao oferecer avaliações objetivas e padronizadas, o protótipo contribui para maior consistência na correção técnica e para a autonomia dos atletas durante os treinos individuais.

Além disso, a implementação em tempo real, com taxa média de processamento de aproximadamente 21–22 FPS, mostrou-se satisfatória para manter a fluidez na interação com o usuário. Essa característica é especialmente importante em contextos esportivos, onde o *feedback* instantâneo pode impactar diretamente na qualidade da execução.

Em síntese, este trabalho reforça a viabilidade do uso da inteligência artificial e da visão computacional na prática esportiva, com foco no fisiculturismo. O protótipo desenvolvido, embora limitado a uma única pose no estado atual, abre caminho para aplicações mais amplas, seja no aperfeiçoamento técnico dos atletas, na redução da subjetividade de julgamentos em competições ou até mesmo no auxílio à prevenção de lesões decorrentes de má postura.

5.1 Trabalhos futuros

Para obter melhores resultados e ampliar a aplicabilidade do sistema, são sugeridos os seguintes trabalhos futuros:

- Incorporar novas poses obrigatórias do fisiculturismo, permitindo uma análise mais completa e abrangente do repertório de movimentos avaliados em competições.

- Implementar métricas quantitativas de simetria corporal, como ângulos e distâncias entre pontos-chave, para complementar o *feedback* textual com dados objetivos.
- Explorar técnicas mais avançadas de inteligência artificial, incluindo modelos baseados em *deep learning* com treinamento específico em *datasets* de fisiculturistas, a fim de aumentar a precisão do sistema.
- Desenvolver uma interface gráfica mais intuitiva e interativa, possibilitando maior usabilidade e acessibilidade para atletas de diferentes níveis de experiência.
- Expandir a aplicação do sistema para dispositivos móveis (*smartphones* ou *tablets*), tornando-o portátil e prático para uso em academias.
- Investigar o uso do protótipo em competições simuladas, a fim de avaliar seu potencial como ferramenta auxiliar de arbitragem.

5.2 Considerações Finais

As considerações finais deste trabalho evidenciam a relevância da integração entre visão computacional e fisiculturismo, destacando a possibilidade de automatizar a análise de poses em um esporte cuja avaliação é tradicionalmente subjetiva. O protótipo desenvolvido demonstrou ser capaz de identificar a execução da pose de duplo bíceps, fornecendo *feedback* imediato sobre a correção postural, o que representa um avanço significativo em termos de apoio ao atleta durante seus treinamentos.

Ainda que o sistema apresente limitações, como a restrição a uma única pose e a dependência de condições ambientais adequadas para a captura de imagem, sua implementação abre perspectivas promissoras para o futuro. A aplicação de técnicas de inteligência artificial nesse contexto pode não apenas ampliar a precisão das análises, mas também contribuir para democratizar o acesso a ferramentas de avaliação técnica, beneficiando atletas de diferentes níveis.

Assim, este estudo reforça a importância da interdisciplinaridade entre ciência da computação e ciências do esporte, demonstrando como a tecnologia pode potencializar o desempenho humano. Espera-se que, a partir desta pesquisa, novas investigações sejam conduzidas para ampliar as funcionalidades do sistema e consolidar sua aplicabilidade prática no cenário esportivo contemporâneo.

REFERÊNCIAS

- ARNOLD, Arnold; DUBIN, Bill. *The new encyclopedia of modern bodybuilding*. New York: Simon & Schuster, 2005.
- BALLARD, Dana H.; BROWN, Christopher M. *Computer vision*. Englewood Cliffs: Prentice Hall, 1982.
- BIRD, Stephen. *Strength training for bodybuilding*. Abingdon: Routledge, 2018.
- BOMPA, Tudor; CORNACCHIA, Lorenzo. *Serious strength training*. 2. ed. Champaign: Human Kinetics, 2000.
- BRADSKI, Gary. The OpenCV Library. *Dr. Dobb's Journal of Software Tools*, 2000.
- CAO, Zhe et al. Realtime multi-person 2D pose estimation using part affinity fields. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017.
- CAO, Zhe et al. OpenPose: Realtime multi-person 2D pose estimation using part affinity fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 43, n. 1, p. 172–186, 2021.
- DOSOVITSKIY, Alexey et al. An image is worth 16x16 words: transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*, 2021.
- FANG, Haoshuo et al. AlphaPose: Whole-body regional multi-person pose estimation and tracking in real-time. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022.
- FORSYTH, David A.; PONCE, Jean. *Computer vision: a modern approach*. 2. ed. Upper Saddle River: Pearson, 2012.
- GONZALEZ, Rafael C.; WOODS, Richard E. *Digital image processing*. 4. ed. New York: Pearson, 2018.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. *Deep learning*. Cambridge: MIT Press, 2016.
- HACKETT, Daniel A.; JOHNSON, Nigel A.; CHOW, Chin-Moi. Training practices and ergogenic aids used by male bodybuilders. *Journal of Strength and Conditioning Research*, v. 27, n. 6, p. 1609–1617, 2013.
- HARRIS, Charles R. et al. Array programming with NumPy. *Nature*, v. 585, n. 7825, p. 357–362, 2020.

HELMS, Eric; ARAGON, Alan; FITT, Peter. Evidence-based recommendations for natural bodybuilding contest preparation. *Journal of the International Society of Sports Nutrition*, v. 16, n. 1, p. 1–12, 2019.

HUNTER, J. D. Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, v. 9, n. 3, p. 90–95, 2007.

INTERNATIONAL FEDERATION OF BODYBUILDING AND FITNESS (IFBB). *Rules of judging*. Disponível em: <https://ifbb.com>. Acesso em: 2023.

JAIN, Anil K.; FLYNN, Patrick; ROSS, Arun A. *Handbook of biometrics*. New York: Springer, 2007.

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, v. 60, n. 6, p. 84–90, 2017.

LITJENS, Geert et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*, v. 42, p. 60–88, 2017.

LUGARES, Camillo; LUGARES, Esteban. MediaPipe: A Framework for Building Perception Pipelines. *Google AI Blog*, 2019. Disponível em: <https://google.github.io/mediapipe/>. Acesso em: 2023.

PRINCE, Simon J. D. *Computer vision: models, learning, and inference*. Cambridge: Cambridge University Press, 2012.

REDMON, Joseph; FARHADI, Ali. YOLOv3: An incremental improvement. *arXiv preprint arXiv:1804.02767*, 2018.

SANTANA, Fernanda M.; VIEIRA, Lucas H. P. O posing no fisiculturismo: relevância para o desempenho competitivo. *Revista Brasileira de Prescrição e Fisiologia do Exercício*, v. 13, n. 82, p. 1226-1234, 2019.

SCHOENFELD, Brad. *Science and development of muscle hypertrophy*. Champaign: Human Kinetics, 2010.

SZELISKI, Richard. *Computer vision: algorithms and applications*. 2. ed. London: Springer, 2022.

TAN, José. Bodybuilding posing techniques: aesthetics on stage. *Journal of Strength and Conditioning*, v. 45, n. 2, 2021.


WU, Rui; WANG, Yuxuan; ZHANG, Yifan. Computer vision-based human motion analysis in sports: a review. *IEEE Access*, v. 9, p. 123456–123470, 2021.

WU, Yiming et al. Artificial intelligence applications in sports: a review. *Journal of Sports Sciences*, v. 39, n. 18, p. 2057–2068, 2021.

ZHAO, Wenyi; CHELLAPPA, Rama; PHILLIPS, P. Jonathon; ROSENFELD, Azriel. Face recognition: A literature survey. *ACM Computing Surveys*, v. 35, n. 4, p. 399–458, 2003.

ZHENG, Chuanming et al. Deep learning-based human pose estimation: a survey. *arXiv preprint arXiv:2006.01423*, 2020.

APÊNDICE A – IMAGENS DOS TESTES



Teste de caso - Posição completamente fora de pose



Teste de caso - Cotovelos Baixos



Teste de caso - Angulação Incorreta entre braço e antebraço



Teste de caso - Pose Correta

APÊNDICE B – CÓDIGO FONTE

```
bodyVision.py

# Importa bibliotecas essenciais para visão computacional,
matemática e tempo
import cv2
import mediapipe as mp
import math
import numpy as np
import time

# Classe responsável por detectar e avaliar poses humanas
class PoseDetector:
    def __init__(self, static_image_mode=False,
min_detection_confidence=0.5, min_tracking_confidence=0.5):
        # Inicializa os módulos do MediaPipe Pose
        self.mp_pose = mp.solutions.pose
        self.pose =
self.mp_pose.Pose(static_image_mode=static_image_mode,
min_detection_confidence=min_detection_confidence,
min_tracking_confidence=min_tracking_confidence)
        self.mp_drawing = mp.solutions.drawing_utils

        # Calcula o ângulo formado entre três pontos (por
exemplo: ombro, cotovelo e pulso)
        @staticmethod
        def calculate_angle(a: list[float], b: list[float], c:
list[float]) -> float:
            ba = [a[0] - b[0], a[1] - b[1]]
            bc = [c[0] - b[0], c[1] - b[1]]
            dot_product = ba[0] * bc[0] + ba[1] * bc[1]
            magnitude_ba = math.sqrt(ba[0]**2 + ba[1]**2)
            magnitude_bc = math.sqrt(bc[0]**2 + bc[1]**2)
            if magnitude_ba == 0 or magnitude_bc == 0:
                return 0
            angle_radians = math.acos(dot_product / (magnitude_ba
* magnitude_bc))
            return math.degrees(angle_radians)

        # Avalia a postura "duplo bíceps" com base em altura dos
cotovelos e ângulo dos braços
        @staticmethod
        def evaluate_double_biceps(left_angle, right_angle,
left_elbow_height, right_elbow_height, left_shoulder_height,
right_shoulder_height):
            errors = []
            if left_elbow_height > left_shoulder_height:
                errors.append("Cotovelo esquerdo muito baixo")
```

```

        if right_elbow_height > right_shoulder_height:
            errors.append("Cotovelo direito muito baixo")
        if not 30 <= left_angle <= 80:
            errors.append("Angulo do braco esquerdo fora do
intervalo (30-80 graus)")
        if not 30 <= right_angle <= 80:
            errors.append("Angulo do braco direito fora do
intervalo (30-80 graus)")
        if errors:
            return "Posicao incorreta - " + "; ".join(errors)
+ "."
        return "Posicao correta - Excelente postura!"

    # Verifica se o usuário está centralizado horizontalmente
na imagem
    @staticmethod
    def evaluate_centered(shoulder_left_x, shoulder_right_x,
width):
        center_x = width // 2
        body_center_x = (shoulder_left_x + shoulder_right_x)
// 2
        offset = abs(center_x - body_center_x)
        threshold = width * 0.1
        if offset < threshold:
            return "Usuario bem centralizado na imagem."
        else:
            return "Centralize-se melhor na camera para
avaliacao precisa."

    # Processa um frame individual e aplica a avaliação da
pose
    def process_frame(self, frame,
pose_mode='double_biceps'):
        image_rgb = cv2.cvtColor(frame, cv2.COLOR_BGR2RGB)
        results = self.pose.process(image_rgb)

        if results.pose_landmarks:
            self.mp_drawing.draw_landmarks(frame,
results.pose_landmarks, self.mp_pose.POSE_CONNECTIONS)
            landmarks = results.pose_landmarks.landmark
            h, w, _ = frame.shape

            def get_pixel_point(landmark):
                return int(landmark.x * w), int(landmark.y *
h)

            # Obtém pontos importantes dos dois braços
            points = {}
            for name in ["LEFT_SHOULDER", "LEFT_ELBOW",
"LEFT_WRIST", "RIGHT_SHOULDER", "RIGHT_ELBOW",
"RIGHT_WRIST"]:

```

```

        landmark_enum =
getattr(self.mp_pose.PoseLandmark, name)
        points[name] =
get_pixel_point(landmarks[landmark_enum.value])

        # Calcula os ângulos dos dois braços
        angle_left =
self.calculate_angle(points["LEFT_SHOULDER"],
points["LEFT_ELBOW"], points["LEFT_WRIST"])
        angle_right =
self.calculate_angle(points["RIGHT_SHOULDER"],
points["RIGHT_ELBOW"], points["RIGHT_WRIST"])

        # Avalia a pose de acordo com o modo
        if pose_mode == 'double_biceps':
            pose_quality = self.evaluate_double_biceps(
                angle_left, angle_right,
                points["LEFT_ELBOW"][1],
points["RIGHT_ELBOW"][1],
                points["LEFT_SHOULDER"][1],
points["RIGHT_SHOULDER"][1]
            )
        elif pose_mode == 'enquadramento':
            pose_quality = self.evaluate_centered(
                points["LEFT_SHOULDER"][0],
points["RIGHT_SHOULDER"][0], w
            )
        else:
            pose_quality = f"Modo '{pose_mode}' ainda nao
implementado"

        font = cv2.FONT_HERSHEY_SIMPLEX
        text_color = (0, 255, 0) if
pose_quality.startswith("Posicao correta") or "centralizado"
in pose_quality else (0, 0, 255)

        for side in ["LEFT", "RIGHT"]:
            cv2.line(frame, points[f"{side}_SHOULDER"],
points[f"{side}_ELBOW"], (255, 255, 0), 2)
            cv2.line(frame, points[f"{side}_ELBOW"],
points[f"{side}_WRIST"], (255, 255, 0), 2)
            angle = angle_left if side == "LEFT" else
angle_right
            cv2.putText(frame, f"{int(angle)}°",
points[f"{side}_ELBOW"], font, 0.7, (139, 0, 0), 2)

        # Ajusta quebra de linha manual para textos
        longos
        lines = []
        max_chars = 70
        while len(pose_quality) > max_chars:

```

```

split_index = pose_quality.rfind(';', 0,
max_chars)
    if split_index == -1:
        split_index = max_chars
    lines.append(pose_quality[:split_index +
1].strip())
    pose_quality = pose_quality[split_index +
1:].strip()
    lines.append(pose_quality)

    y = 20
    for line in lines:
        text_size, _ = cv2.getTextSize(line, font,
0.8, 2)
        x_center = (w - text_size[0]) // 2
        cv2.rectangle(frame, (x_center - 20, y),
(x_center + text_size[0] + 20, y + 40), (0, 0, 0), -1)
        cv2.putText(frame, line, (x_center, y + 30),
font, 0.8, text_color, 2)
        y += 45

    return frame

# Função principal que inicializa a câmera e exibe os
resultados em tempo real
def main():
    detector = PoseDetector()
    cap = cv2.VideoCapture(0)
    if not cap.isOpened():
        print("Erro ao acessar a camera.")
        return

    window_name = 'Pose Detection'
    cv2.namedWindow(window_name, cv2.WINDOW_NORMAL)
    cv2.resizeWindow(window_name, 1920, 1080)

    prev_time = time.time()
    pose_mode = 'double_biceps'

    while cap.isOpened():
        ret, frame = cap.read()
        if not ret:
            print("Erro ao capturar frame.")
            break

        frame = cv2.resize(frame, (1920, 1080))
        frame = detector.process_frame(frame, pose_mode)

        # Exibe FPS e Modo em posições mais baixas para não
sobrepor texto principal
        curr_time = time.time()

```

```

        fps = 1 / (curr_time - prev_time)
        prev_time = curr_time
        cv2.putText(frame, f"FPS: {int(fps)}", (30, 180),
cv2.FONT_HERSHEY_SIMPLEX, 0.8, (255, 255, 255), 2)
        cv2.putText(frame, f"Modo: {pose_mode}", (30, 140),
cv2.FONT_HERSHEY_SIMPLEX, 0.8, (100, 255, 255), 2)

        instruction_text = "Pressione 'Q' para sair | '1':
Biceps | '2': Enquadramento"
        text_size, _ = cv2.getTextSize(instruction_text,
cv2.FONT_HERSHEY_SIMPLEX, 0.7, 2)
        cv2.putText(frame, instruction_text, (1920 -
text_size[0] - 30, 1080 - 30), cv2.FONT_HERSHEY_SIMPLEX, 0.7,
(200, 200, 200), 2)

        cv2.imshow(window_name, frame)

        key = cv2.waitKey(1) & 0xFF
        if key == ord('q'):
            break
        elif key == ord('1'):
            pose_mode = 'double_biceps'
        elif key == ord('2'):
            pose_mode = 'enquadramento'

        cap.release()
        cv2.destroyAllWindows()

# Executa a função principal
if __name__ == "__main__":
    main()

```



**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
GABINETE DO REITOR**

Av. Universitária, 1069 • Setor Universitário
Caixa Postal 86 • CEP 74605-010
Goiânia • Goiás • Brasil
Fone: (62) 3946.1000
www.pucgoias.edu.br • reitoria@pucgoias.edu.br

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O estudante LUIZ SABINO DA SILVA BISNETO do Curso de CIÊNCIA DA COMPUTAÇÃO matrícula 2021.1.0028.0022-2, telefone: 62991768655 e-mail 2021.1.0028.0022-2@pucgo.edu.br, na qualidade de titular dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado Visão computacional para o auxílio na execução de poses no fisiculturismo, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 29 de setembro de 2025.

LUIZ SABINO DA SILVA Assinado de forma digital por LUIZ
BISNETO:01316884210 SABINO DA SILVA BISNETO:01316884210
Dados: 2025.09.29 15:04:18 -03'00'

Assinatura do autor: _____

Nome completo do autor: LUIZ SABINO DA SILVA BISNETO

Documento assinado digitalmente



GUSTAVO SIQUEIRA VINHAL
Data: 29/09/2025 12:26:28-0300
Verifique em <https://validar.iti.gov.br>

Assinatura do professor-orientador: _____

Nome completo do professor-orientador: GUSTAVO SIQUEIRA VINHAL